
CENTRO UNIVERSITÁRIO UNIFACVEST¹
CURSO DE ENGENHARIA ELÉTRICA
CARLOS GUILHERME HACKBART

TCC:
DESENVOLVIMENTO E IMPLEMENTAÇÃO DE UMA REDE NEURAL ARTIFICIAL NO
CONVERSOR CC-CC REBAIXADOR DE TENSÃO BUCK

LAGES
2020

¹ Os argumentos e estrutura do TCC estão nos passos metodológicos do livro de metodologia, p.44 a p.53: RODRIGUES, Renato. Gonçalves, José Correa. **Procedimento de metodologia científica**. 9.ed. Lages, SC. PAPERVEST. 2020. Disponível em Material Acadêmico UNIFACVEST, Biblioteca Física UNIFACVEST ou prpe@unifacvest.edu.br.

CARLOS GUILHERME HACKBART

**TCC:
DESENVOLVIMENTO E IMPLEMENTAÇÃO DE UMA REDE NEURAL ARTIFICIAL NO
CONVERSOR CC-CC REBAIXADOR DE TENSÃO BUCK**

Relatório de TCC apresentado ao
Centro Universitário UNIFACVEST,
como parte dos requisitos para obtenção
do título de Bacharel em Engenharia
Elétrica.

Prof.(a) Orientador (a):
Franciéli Lima de Sá Biasiolo
Coordenador do Curso:
Franciéli Lima de Sá Biasiolo.

CARLOS GUILHERME HACKBART

TCC:
DESENVOLVIMENTO E IMPLEMENTAÇÃO DE UMA REDE NEURAL ARTIFICIAL NO
CONVERSOR CC-CC REBAIXADOR DE TENSÃO BUCK

Relatório de TCC apresentado ao
Centro Universitário UNIFACVEST,
como parte dos requisitos para obtenção
do título de Bacharel em Engenharia
Elétrica.

Prof.(a) Orientador (a):
Francieli Lima de Sá Biasiolo
Coordenador do Curso:
Francieli Lima de Sá Biasiolo.

Lages, SC 08 / 07 / 2020. Nota 10,0 Francieli Lima de Sá Biasiolo
(data de aprovação) (assinatura do orientador- assinatura-digital ou scammer)

Francieli Lima de Sá Biasiolo
(coordenador do curso de graduação, nome e assinatura-digital ou scammer)

Artigo apresentado ao Centro Universitário Facvest – UNIFACVEST, como requisito necessário para a obtenção do título de Bacharel em Engenharia Elétrica.

Carlos Guilherme Haackbart

NOME DO ALUNO

Desenvolvimento e Implementação de uma Rede Neural Artificial no Conversor CC-CC Relutância de Tensão Buck

TÍTULO DO TRABALHO

BANCA EXAMINADORA:

Francieli Lima de Sá Biasiolo, Dra.

Titulação e nome do Orientador (a)

Msc Eng. Eletricista Silvio Moraes de Oliveira

Titulação e nome do Avaliador (a).

Msc. Nathulle Waldriques Branco.

Titulação e nome do Avaliador (a).

Francieli Lima de Sá Biasiolo

Coordenador (a) Prof. (a). Titulação e nome da Coordenador (a).

Lages, 08 de julho de 2020.

DESENVOLVIMENTO E IMPLEMENTAÇÃO DE UMA REDE NEURAL ARTIFICIAL NO CONVERSOR CC-CC REBAIXADOR DE TENSÃO BUCK

Carlos Guilherme Hackbart¹

Francieli Lima de Sá²

RESUMO

As redes neurais artificiais são modelos matemáticos baseados no comportamento do cérebro humano. Elas podem aprender e modelar informações entre entradas e saídas, lineares ou não; realizar previsões; monitorar padrões, obtendo precisão no processo de decisão. Este trabalho tem como objetivo projetar uma rede neural artificial para um conversor cc-cc rebaixador de tensão, Buck, a fim de realizar o controle do fluxo de potência entre a entrada e saída do conversor. A rede neural artificial realizará o amortecimento da tensão no regime transitório durante a troca de carga no conversor, buscando eficiência e proteção do equipamento a ser trabalhado e por fim demonstrar os resultados obtidos através de simulações computacionais e através de comparações com o controle digital PI (Proportional Integral), um dos mais utilizados para esse conversor.

Palavras-chave: Rede Neural Artificiais. Controle. Conversor. Sistema.

ABSTRACT

Artificial neural networks are mathematical models based on human brain behavior. They can learn and to mold information between inputs and outputs, linear or not; make predictions; monitor pattern, getting accuracy on the decision process. This work has the objective to design one artificial neural network to dc-dc converter voltage lowerer, Buck, in order to accomplish the control of power flow between the input and output of the converter. Artificial Neural Network will accomplish the voltage cushioning during the transitional regime of load exchange on the converter, pursuing efficiency and

¹ Acadêmico de graduação do curso de Engenharia Elétrica – UNIFACVEST
E-mail: cgharckbart@gmail.com

² Dra. Eng. Eletricista, Professora e coordenadora do curso de Engenharia Elétrica – UNIFACVEST. E-mail: francielimadesa@gmail.com

protection of the equipment to be worked and to demonstrate the results through computer simulations and through comparisons with PI digital control, one of the most used for this converter.

Keywords: Artificial neural network. Control. Converter. System.

1 INTRODUÇÃO

Os conversores cc-cc de potência têm sido amplamente utilizados em sistemas eletrônicos que requerem uma alta confiabilidade, além da forte presença na geração fotovoltaica, em sistemas de frenagem regenerativa de carros elétricos, são encontrados trabalhando com equipamentos desde a parte de geração até a distribuição e entre outras aplicações. Entre estes conversores um que vem sendo muito utilizado é o conversor Buck, responsável por rebaixar a tensão lida na entrada do conversor entregando na sua saída o valor de tensão projetado.

Uma forma mais eficiente de trabalhar com o Buck é utilizá-lo em malha fechada onde um controle externo realiza a leitura de todo o sistema fazendo o conversor trabalhar com a maior eficiência possível. Sendo uma forma de controle, ainda não muito explorada, a rede neural artificial, a qual é o controle estudado neste trabalho.

Uma Rede Neural Artificial é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural de armazenar conhecimento experimental e torná-lo disponível para uso. (HAYKIN, 2001).

RNA (Rede Neural Artificial) se mostra ser uma das melhores opções a ser aplicada em vários sistemas, devido a sua precisão e rapidez. Saber a eficácia do seu uso em um sistema não linear como o controle de um conversor estático é um estudo que pode trazer grandes ganhos para a área da eletrônica de potência.

Tendo estas informações este trabalho tem como objetivo projetar uma rede neural artificial para realizar o controle do fluxo de potência na saída do conversor CC-CC rebaixador de tensão, Buck, utilizando as linguagens de programação Python e C. Este artigo se dividirá em cinco partes, sendo a primeira uma demonstração de algumas aplicações existentes quanto ao uso da rede neural artificial. Na segunda parte uma


introdução do sistema proposto, suas características e seu modelo de criação. Na terceira parte está descrito os predicativos do controle PI utilizado na comparação. Na quarta parte se encontra os resultados obtidos através de simulações computacionais e por fim a quinta parte que se trata da conclusão obtida neste trabalho.

2 APLICAÇÕES

Neste trabalho, a rede neural artificial é aplicada em um conversor estático de potência, mas este tipo de controle não se restringe à engenharia elétrica, ela pode ser aplicada em vários tipos de sistemas e em diversas áreas como a da saúde, segurança, finanças entre muitas outras.

Um dos sistemas que vem usufruindo da RNA é o sistema de reconhecimento de objetos, este sendo a principal aplicação de uma rede neural artificial em um carro autônomo por exemplo. Carros como os da Tesla utilizam uma rede neural conhecida como Convolutional Neural Network (Rede Neural Convolutacional) combinada com outros tipos. Esta arquitetura de rede neural trabalha com uma base de dados de imagens, como mostra a figura abaixo.

Figura 01 – Rede Neural Convolutacional.




Fonte: (SAHA, 2018).

Trazendo uma aplicação para mais perto do trabalho apresentado, nos carros elétricos existem sistemas que trabalham com frenagem regenerativa. Segundo Paredes (2013), o processo da frenagem regenerativa é aplicado em veículos elétricos que porque permite que se recupere a energia cinética disponível na desaceleração do veículo, levando a energia regenerada para elementos de armazenamento para ser reutilizada.

Figura 02 – Modelo de carro elétrico.

■ **Visão Estrutural**

Esta seção mostra os principais componentes estruturais do Nissan LEAF e suas funções.

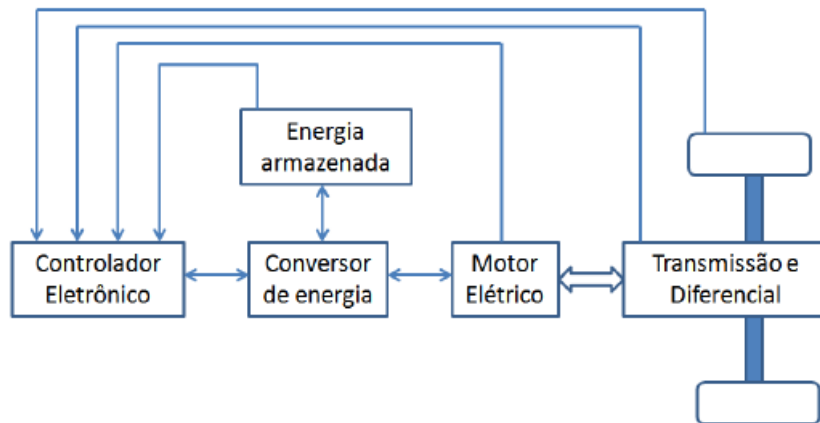


Fonte: (LENZ, 2013).

Mas o principal motivo deste sistema ter sido mencionado é que ele utiliza um conversor Buck para rebaixamento da tensão, gerada na tração, para as baterias ou para outros sistemas internos. Neste ponto temos a rede neural artificial, ela trabalha como controle desse conversor obtendo a melhor eficiência no fluxo de potência interno, e o melhor de tudo é que a RNA projetada neste trabalho pode ser utilizada neste sistema de frenagem regenerativa (realizando apenas a mudança da tensão de saída).

Com o auxílio da Figura 03 podemos ver que em um sistema de frenagem regenerativa todo o fluxo de potência passa pelo conversor estático, representado na imagem pelo bloco Controlador Eletrônico.

Figura 03 – Representação de um sistema de frenagem regenerativa.



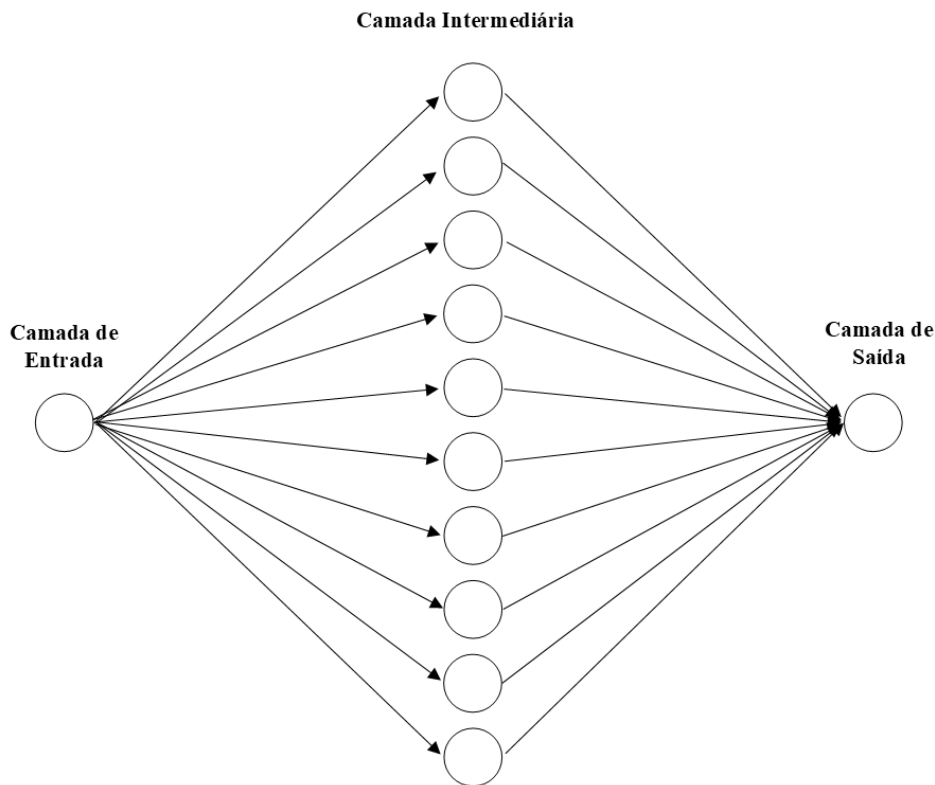
Fonte: (PAREDES, 2013).

A rede neural possui várias aplicações em diversos sistemas, inclusive a rede neural aqui projetada, que pode ser utilizada em um conversor Buck e este conversor pode ser utilizado em vários sistemas, como por exemplo um sistema de frenagem regenerativa.

3 SISTEMA PROPOSTO

Quando se fala de uma rede neural artificial estamos tratando de um assunto praticamente abstrato pois não se pode realmente ver uma rede neural e este detalhe pode acabar dificultando a compreensão do seu funcionamento. Para isso a Figura 04 nos traz um desenho simbólico de como seria uma rede neural artificial.

Figura 04 – Demonstração gráfica da rede neural artificial.



Fonte: Autoria Própria (2020).

Na Figura 04 podemos notar que a rede neural é dividida em três camadas: camada de entrada, camada intermediária ou camada de saída. Sendo a camada de entrada responsável por receber os dados do sistema; a camada intermediária responsável por armazenar funções matemáticas e realizar seus devidos cálculos com os valores percebidos pela camada de entrada; e por fim a camada de saída, esta que também pode

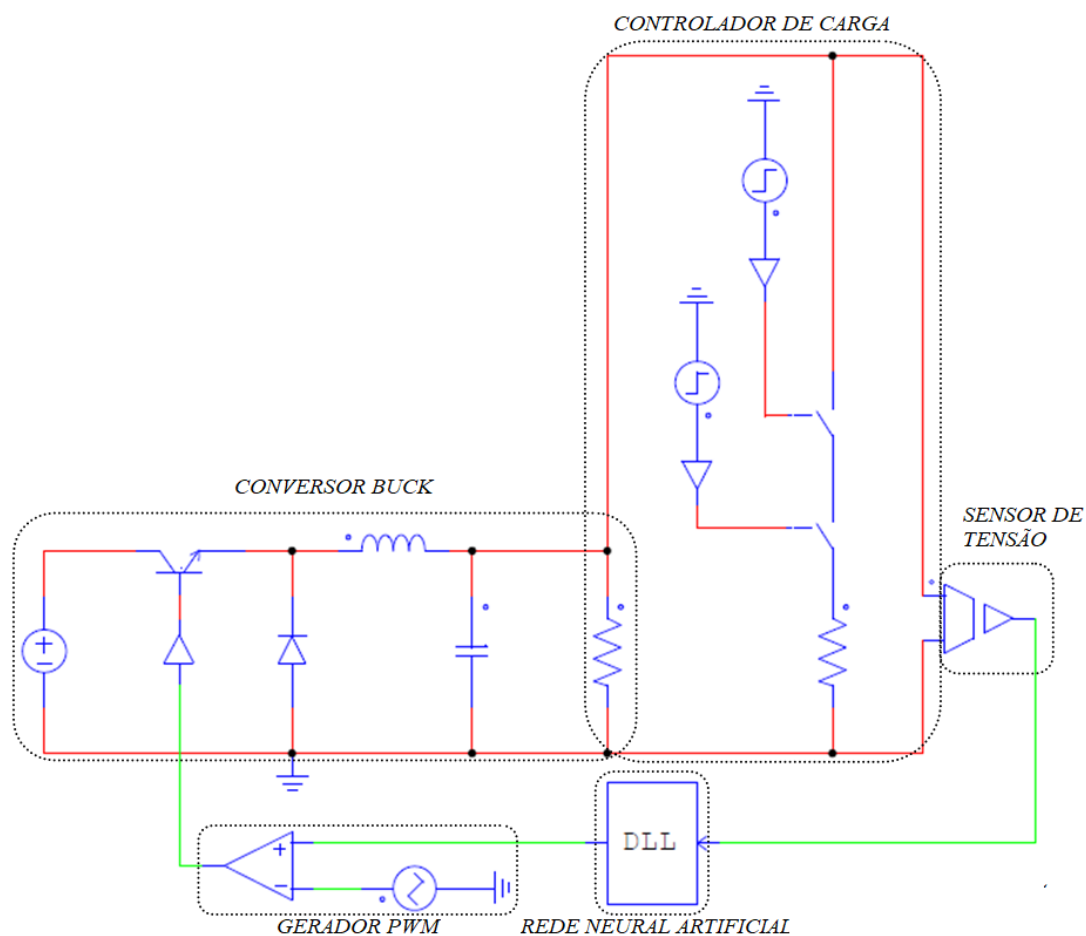
possuir modelos matemáticos, é responsável por levar os dados preditos pela rede neural artificial para o sistema.

Essas flechas que ligam as três camadas possuem um valor inseridos nela, conhecidos como pesos sinápticos, e é exatamente este valor que a rede neural tenta aprimorar durante seu processo de funcionamento.

A Figura 05 apresenta o sistema proposto, no qual consiste de um conversor estático tipo Buck, que trabalha no rebaixamento da tensão de 200V para 100V e como controle uma rede neural que tem o propósito de controlar um fluxo de potência do conversor.

Para realizar o controle da potência do conversor o transistor recebe uma onda PWM (Pulse Width Modulation – Modulação Por Largura de Pulso), sendo a frequência constante de 50MHz e o duty cycle gerado pela RNA.

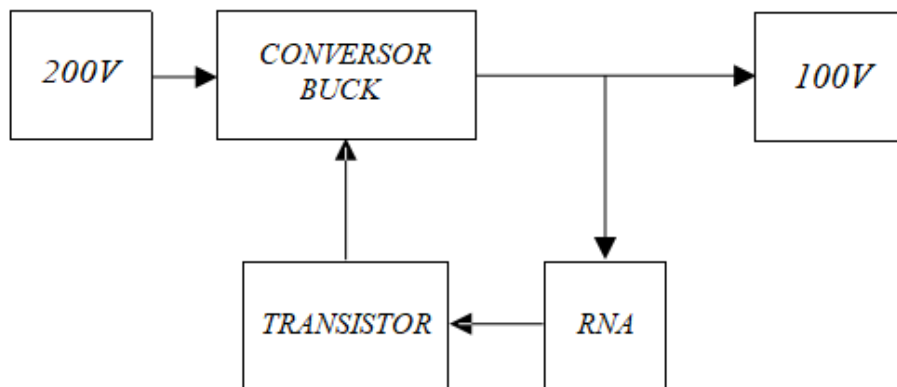
Figura 05 – Bloco do sistema completo



Fonte: Autoria própria (2020).

Mesmo com a troca de carga no conversor a rede neural tem o papel manter a tensão de saída sempre no valor de 100V e com o máximo de eficiência possível. As duas chaves, com sinal de onda próprio, localizadas na saída do conversor tem a característica de simular a entrada e saída de carga no sistema. O processo de todo o funcionamento do sistema pode ser entendido através da Figura 06.

Figura 06 – Diagrama de blocos do sistema.



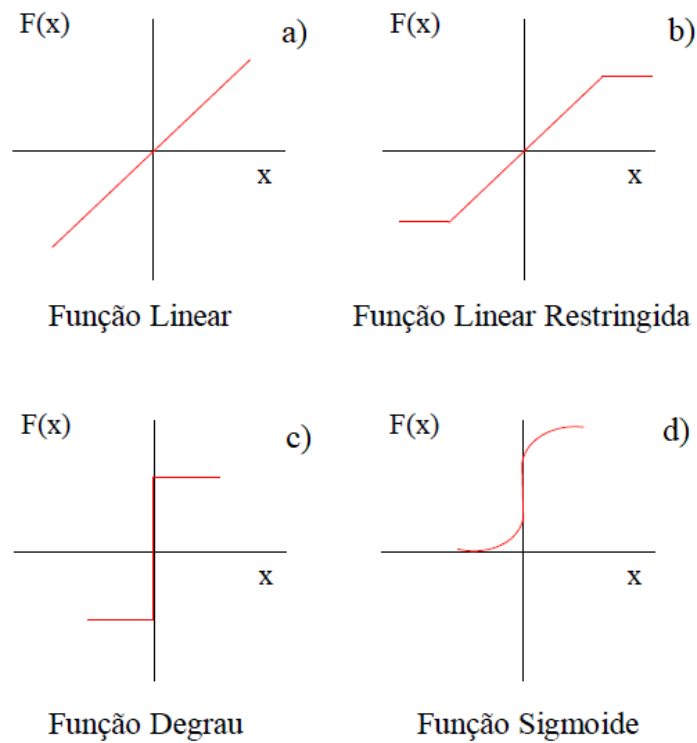
Fonte: Autoria própria (2020).

3.1 Função de Transferência

A função de transferência que também pode ser chamada de função de ativação é um importante agente em uma rede neural artificial. Segundo Tonon (2014) a função de ativação tem como objetivo definir o tipo de saída que o neurônio irá fornecer baseado no sinal de ativação vindo do processo de soma anterior. A função de ativação está diretamente relacionada com o tipo de saída pretendido da rede neural.

Na Figura 07 exemplo a) e b) temos a representação gráfica de duas funções de ativação sendo ambas lineares. Na função linear o valor percebido pela camada de entrada é multiplicado por uma constante real que definirá uma saída linear, ela também pode ser delimitada por um range de valores.

Na Figura 07 exemplo c) e d) temos dois exemplos de funções de ativação: função Degrau e a função Sigmoide. Na função Degrau obtemos uma saída binária onde geralmente os valores são 0 ou 1. Já na função Sigmoide, sendo esta não linear, temos um range de valores entre 0 e 1 e sendo esta utilizada como função de ativação da rede neural proposta.

Figura 07 – Exemplos de funções de transferência.

Fonte: Autoria própria (2020).

3.2 Características do conversor Buck

Devido o conversor aqui estudado ser apenas um modelo para estudo da aplicação da rede neural, suas características não possuem um propósito específico, sendo assim, o conversor escolhido trabalha com uma tensão de entrada de 200V e uma tensão de saída de 100V e uma potência de 500W. Os valores dos componentes para trabalhar com esta potência são mostrados na Tabela 01. Aqui estamos utilizando o conversor Buck, mas a rede neural pode ser utilizada em qualquer outro conversor estático, basta realizar a modelagem correta para cada tipo.

Tabela 01 – Informações do Conversor Boost.

Conversor Boost		
Capacitor	Indutor	Resistor
1.29×10^{-6} F	2×10^{-3} H	20 Ω
Frequência de Chaveamento		Duty Cycle
50 kHz		0.5

Fonte: Autoria própria (2020).

3.3 Modelagem da Rede Neural Artificial

A programação da RNA foi realizada em duas partes, sendo a primeira a criação do modelo e treinamento da RNA e a segunda parte sendo responsável por realizar o trabalho real de controle do conversor.

A RNA foi projetada e desenvolvida na linguagem Python, sendo esta escolhida devido ser uma linguagem amplamente utilizada pelos projetistas de redes neurais artificiais e por ter uma extensa biblioteca voltada para este assunto. A plataforma de desenvolvimento escolhida foi Jupyter Notebook 4.2.3 pois permite criar blocos de programação e executá-los separadamente.

Para criar a rede neural foi necessário o uso da API (Application Programming Interface – Interface de programação de aplicações) Keras no qual nos permite utilizar bibliotecas de deep learning (aprendizagem profunda). O modelo Sequential se mostrou mais eficiente para este tipo de sistema, sendo assim o escolhido.

O princípio base de funcionamento de uma rede neural é encontrar padrões entre os valores de entrada e saída fornecidos nas bases de treinamento. Só que se as bases de dados estiverem inseridas na rede neural com uma configuração padrão, por exemplo: 60,0; 60,1; 70,0; 70,1 e assim por diante, nesse caso nota-se que segue em padrão entre o intervalo dos números e isso pode acabar influenciando a rede neural ao erro na hora de encontrar o padrão entre as entradas e saídas.

Para burlar essa característica, os valores da base de dados foram inseridos aleatoriamente como demonstra a soma das matrizes abaixo.

Matriz 01 – Escolha da base de dados de entrada

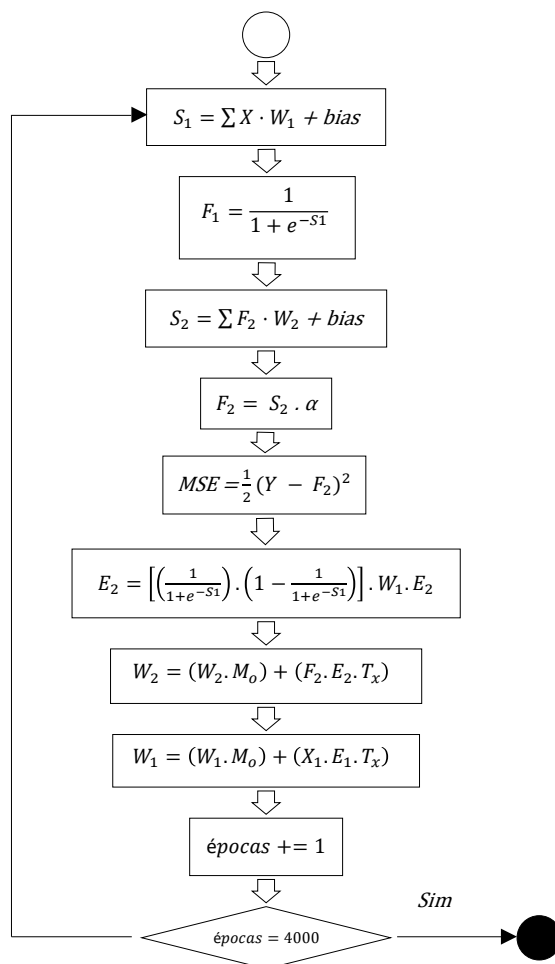
$$\begin{bmatrix} \text{random}(0 - 1) \\ \text{random}(0 - 1) \\ \text{random}(0 - 1) \\ \vdots \\ \text{random}(0 - 1) \end{bmatrix} + \begin{bmatrix} 60 \\ 61 \\ 62 \\ \vdots \\ n \end{bmatrix} = \begin{bmatrix} 60,2 \\ 61,7 \\ 62,4 \\ \vdots \\ n + 0,3 \end{bmatrix}$$

Fonte: Autoria própria (2020).

No Fluxograma 01 podemos observar um fluxograma que tem o objetivo demonstrar os passos realizados pela RNA em seu treinamento, processo realizado na

etapa um, podemos também observar todos os modelos matemáticos utilizados em sua respectiva ordem.

Fluxograma 01 – Fluxograma de treinamento




Fonte: Autoria própria (2020).

Com a RNA treinada é possível coletar os pesos sinápticos gerados e inseri-los em um outro bloco de programação, este bloco sendo o responsável por executar o trabalho de controle do conversor. Neste ponto, o treinamento não é mais necessário.

Este segundo bloco foi programado na linguagem C, sendo esta linguagem escolhida pela ampla utilização em vários tipos de projetos e em microcontroladores, sendo assim, esta RNA pode ser instalada por exemplo em um microcontrolador simples como o PIC. A plataforma de desenvolvimento escolhida foi o Dev-C++.

Para exemplificar a programação realizada nesta etapa, se pode visualizar através do Fluxograma 02 um fluxograma contendo os modelos matemáticos utilizados em suas respectivas ordens.

Fluxograma 02 – Fluxograma de execução.



Fonte: Autoria própria (2020).

Para melhor visualização dos parâmetros, a tabela a seguir mostra com detalhes a modelagem e as funções utilizadas na criação da rede neural artificial.

Tabela 02 – Informações da rede neural.

Rede Neural Artificial		
Training Inputs	Dense Layers	Shape Dense Layers
363	1	10
Activation Function	Learning Rate	Epochs
Sigmoid e Linear	0.001	4000

Fonte: Autoria própria (2020).

Quanto aos dados utilizados para treinamento (training inputs) 35% deles foram utilizados como validação da precisão e os outros 65% para realizar o treinamento. Após o treinamento podemos observar a precisão da RNA através Figura 09.

4 CONTROLE PI

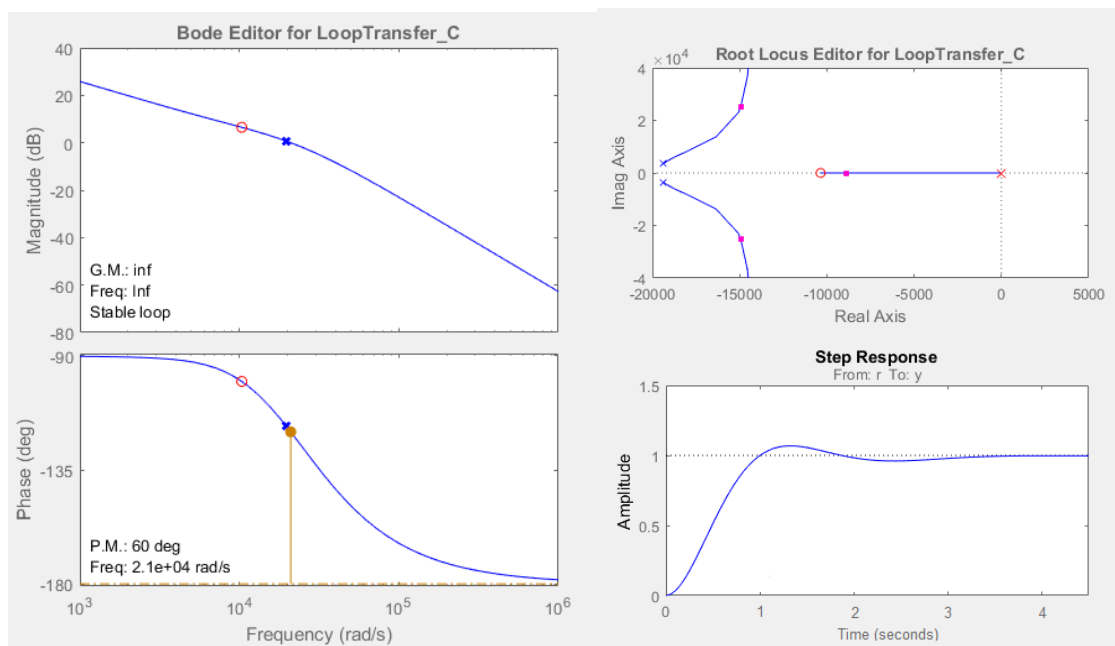
Para verificar e comparar a eficiência do controle realizado pela rede neural, foi desenvolvido um controle PI. Não sendo o foco do trabalho, este tipo de controle não será abordado de forma detalhada. Suas características podem ser observadas na figura e tabela abaixo:

Tabela 03 – Funções do controle digital PI.

Função de Transferência	Função Compensadora
$\frac{200}{2,58 \times 10^{-9} s^2 + 0.0001 s + 1}$	$\frac{0.0094306 (s + 1.036 \times 10^4)}{s}$

Fonte: Autoria própria (2020).

Figura 08 – Características controle digital PI.




Fonte: Autoria própria (2020).

4 RESULTADOS OBTIDOS

A simulação é realizada no conversor estático Buck, projetado pra rebaixar a tensão de 200V para 100V, tendo seu controle realizado através de uma rede neural

artificial, sendo esta, a responsável por manter a tensão de saída estável no conversor sem haver elevada variação no período transitório na troca de carga.

Figura 09 – Precisão no treinamento da RNA.



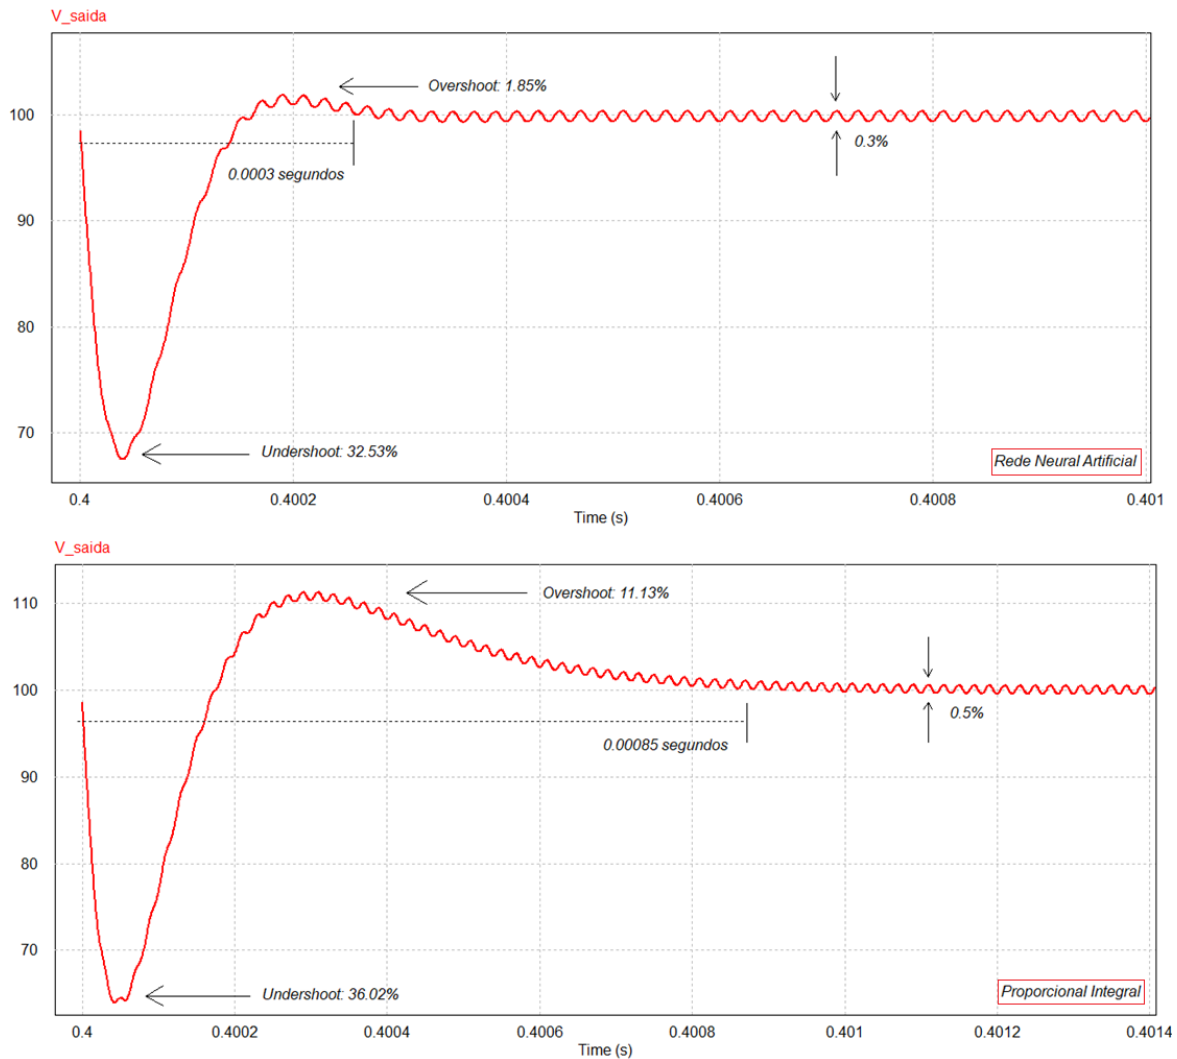
Fonte: Autoria própria (2020).

Na Figura 09 observa-se o desempenho da rede neural artificial durante seu processo de treinamento, onde a linha laranja tende a chegar o mais próximo do valor zero do eixo das ordenadas, implicando que quanto mais próximo do zero menor é a diferença entre o valor gerado pela rede neural e o valor inicialmente setado como sendo o ideal.

O controle Buck possui um predicativo que pode incomodar em muitos sistemas que é ocasionar um pico ou queda de tensão/corrente elevado na entrada e saída de carga, mas por outro lado possui uma rápida resposta de estabilização para o regime permanente. Sabendo desta característica o modelamento da rede neural busca diminuir esse pico e a queda de tensão/corrente.

A Figura 10 mostra, respectivamente, o comportamento da RNA e do PI durante a entrada de carga no sistema no regime transitório e permanente.


Figura 10 – Entrada de carga com controle neural.



Fonte: Autoria própria (2020).

A Figura 11 mostra, respectivamente, o comportamento da RNA e do PI durante a saída de carga no sistema no regime transitório e permanente.

Figura 11 - Saída de carga com controle neural.



Fonte: Autoria própria (2020).

Através das figuras acima se observa a melhora no comportamento da tensão quando utilizado o controle através de rede neural artificial comparado com um controle proporcional integral. Além da redução do regime transitório a rede neural obteve redução nas quedas e picos de tensão. Ambas simulações obtiveram um comportamento subamortecido.

Mesmo com o uso de um controle alternativo, como a rede neural, a senoide formada pelo fluxo de tensão do conversor continua com a presença de altos picos e vales de tensão, mas como foi mostrado por este trabalho, através de um controle alternativo ou até mesmo um controle mais sofisticado podemos reduzir estes picos para valores menores.

5 CONCLUSÃO

A Engenharia assim como outras áreas vem progredindo e usufruindo cada vez mais das tecnologias que nos tem disponível. Sendo a inteligência artificial uma tecnologia muito estudada em vários campos da ciência. Ter um estudo sobre sua eficácia no controle de potência de um conversor estático é algo importante para se avaliar.

Este trabalho teve como objetivo realizar o projeto de uma rede neural artificial e aplica-la em um conversor cc-cc rebaixador de tensão, Buck, de 500W que trabalha com a redução de 200 V para 100V, não tendo uma exata aplicação para esta faixa de potência, mas com intuito de projetar e aplicar uma forma alternativa de controle em um conversor de potência, sendo esta alternativa o uso de redes neurais artificiais.

Através das simulações realizadas pode se concluir que o uso de rede neural artificial para sistemas não lineares como o controle de potência em um conversor estático Buck é totalmente viável, obtendo bons resultados tanto no regime transitório quanto no permanente comparados a modelos já utilizados, um exemplo é o PI que foi utilizado como base de comparação neste trabalho.

Tabela 04 – Resultados das simulações.

		RNA	PI
ENTRADA DE CARGA	REGIME TRANSITÓRIO	0,0003 segundos	0,00085 segundos
	OVERSHOOT	1,85%	11,13%
	UNDERSHOOT	32,53%	36,02%
	PRECISÃO	0,3%	0,5%
SÁIDA DE CARGA	REGIME TRANSITÓRIO	0,00045 segundos	0,0007 segundos
	OVERSHOOT	45,46%	52,64%
	UNDERSHOOT	13,88%	29,99%
	PRECISÃO	0,3%	0,5%

Fonte: Autoria própria (2020).

Na Tabela 04 podemos resumir os resultados obtidos nas simulações e verificar a eficácia do uso de redes neurais artificiais como controlador de conversores estáticos comparado ao conversor proporcional integral.

Este trabalho deixa aberta a discussão para trabalhos futuros no intuito de desenvolver uma rede neural artificial para outras famílias de conversores estáticos trazendo para o mundo da engenharia o que há de mais atual no ramo da tecnologia.

6 REFERÊNCIAS BIBLIOGRÁFICAS

BATSCHAUER, Alessandro Luiz. **Apostila da Disciplina de Controle de Conversores Estáticos**. 2012. 257 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Universidade do Estado de Santa Catarina, Joinville, 2012.

BRAGA, Antônio de Pádua; LUDERMIR, Teresa Bernada; CARVALHO, André Carlos Ponce de Leon Ferreira. **Redes Neurais Artificiais: Teoria e aplicações**. Rio de Janeiro: Ltc Editora, 2000. 142 p.

CARPES, Felipe da Cunha. **Rastreamento de máxima potência fotovoltaica através de redes neurais artificiais perceptron multicamadas**. 2017. 85 f. TCC (Graduação) - Curso de Engenharia Elétrica, Universidade Federal do Pampa, Alegrete, 2017.

CHOLLET, François. **Deep Learning with Python**. 6. ed. -: Manning, 2017. 317 p.

Data Science Academy. **Deep Learning Book**. 2019. Disponível em: <<http://www.deeplearningbook.com.br/>>. Acesso em: 20 junho. 2019.

FELISBINO, Rafael. **Inteligência Artificial e Redes Neurais: Conceitos e Aplicações**. 2012. 47 f. TCC (Graduação) - Curso de Ciência da Computação, Instituto Municipal de Ensino Superior de Assis, Assis, 2012.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. 800 p.

HAYKIN, S. **Redes Neurais: princípios e prática**. 2001. 2 ed. Bookman, Porto Alegre, RS.

JONES, M. Tim. **Um mergulho profundo nas redes neurais recorrentes**. 2017. Disponível em: <<https://imasters.com.br/data/um-mergulho-profundo-nas-redes-neurais-recorrentes>>. Acesso em: 21 junho 2019.

LEITE, Thiago M. **Redes Neurais, Perceptron Multicamadas e o Algoritmo Backpropagation**. 2018. Disponível em: <<https://medium.com/ensina-ai/redes-neurais-perceptron-multicamadas-e-o-algoritmo-backpropagation-eaf89778f5b8>>. Acesso em: 21 junho 2019.

LENZ, André Luiz. **Freio Regenerativo: sistema de recuperação de energia cinética**. Sistema de Recuperação de Energia Cinética. Disponível em: <http://automoveiseletricos.blogspot.com/2013/03/freio-regenerativo-sistema-de.html>. Acesso em: 31 mar. 2013.

MAMANI, Ana Beatriz Alvarez. **Utilização de redes neurais no controle da velocidade de um veículo experimental**. 2004. 122 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Universidade Estadual de Campinas, Campinas, 2004.

MATSUNAGA, Victoria Yukie. **Curso de Redes Neurais Utilizando o MATLAB**. 2012. 22 p.

NIED, Ademir. **Treinamento de redes neurais artificiais baseado em sistemas de estrutura variável com taxa de aprendizado adaptativa**. 2007. 128 f. Tese (Doutorado) - Curso de Engenharia Elétrica, Universidade Federal de Minas Gerais, Belo Horizonte, 2007.

OLIVEIRA NETO, José Rodrigues de. **Excitação de Redes Neurais Pulsadas em Tempo Real: Sistema Conversor/Codificador em FPGA e Amostradores**. 2015. 136 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Universidade Federal de Pernambuco, Recife, 2015.

PAREDES, Marina Gabriela Sadith Perez. **Frenagem Regenerativa em Veículo Elétrico Acionado por Motor de Indução: Estudo, Simulação e Verificação**

Experimental. 2013. 115 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Universidade Estadual de Campinas, Campinas, 2013. Cap. 02.

PIÃO, Silvano Sotelo. **Implementação de rede neural artificial em FPGA utilizando VHDL.** 2012. 66 f. TCC (Graduação) - Curso de Engenharia Elétrica, Escola de Engenharia São Carlos, São Carlos, 2012.

RASHID, Muhammad H. **Eletrônica de potência.** Tradução Leonardo Abramowicz; revisão técnica Carlos Marcelo de Oliveira Stein. – 4. Ed. – São Paulo: Pearson Education do Brasil, 2014.

SAHA, Sumit. **A Comprehensive Guide to Convolutional Neural Networks — the ELI5 way.** Disponível em: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>. Acesso em: 15 dez. 2018.

SEGATTO, E. C.; COURY, D. V. Redes neurais artificiais recorrentes aplicadas na correção de sinais distorcidos pela saturação de transformadores de corrente. **Sba: Controle & Automação Sociedade Brasileira de Automática**, v. 17, n. 4, p. 424-436, 2006.

SOUZA, Allex de Lima et al. **Redes Neurais Convolucionais Aplicadas ao Processo de Classificação de Cultivares de Guaranazeiros.** In: XIV Encontro Nacional de Inteligência Artificial e Computacional, 2017, Uberlândia. 10 p.

TONON, Thiago. **Controle neural aplicado a um conversor Boost utilizado em aerogeradores de baixa potência.** 2014. 71 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Universidade Tecnológica Federal do Paraná, Cornélio Procópio, 2014.